المجلة العراقية للعلوم الاحصائية (10) 2006
ص ص [30–47]

استخدام الشبكات العصبية في تقدير رتب سلاسل ماركوف مع التطبيق على سلسلة جبال بطمة في محافظة نينوى

د. باسل يونس الخياط* د. احمد محمود السبعاوي** ابتهاج عبدالحميد الكسو***

الملخص

لقد اولى الباحثون اهتماماً خاصاً بدراسة السلاسل الماركوفية باعتبارها احد النماذج الاحتمالية التي وجد لها العديد من التطبيقات، ومن الامور المهمة المتعلقة بدراسة سلاسل ماركوف التي شغلت اهتمام الباحثين تقدير رتبتها. واحدى طرائق تقدير الرتبة تعتمد على تقنيات الذكاء الاصطناعي المتمثل باسلوب الشبكات العصبية. وقد اعتمدت شبكة المدرك لتمييز الرتب واعدت خوارزمية خاصة لتدريب تلك الشبكة وبنيت شبكة لهذا الغرض، سميت (Order Neural Network) (ONN)، دربت على مجموعة من السلاسل الماركوفية والمولدة بالمحاكاة. وتمت معالجة بيانات واقعية لتتابعات صخرية ماخوذة من منطقة جبل بطمة باعتبارها سلسلة ماركوف وقدرت رتبة هذه السلسلة على انها الثالثة.

Using Neural Networks in order Estimation of Markov's Chain with an Application at Batma Chains in Nineveh Governorate

ABSTRACT

The researchers have payed attention to the study of Markovian Chains, since they are considered as one of the probabilistic models which many applications were found about it in different fields. One of the important matters related to the study of Markovian chains that have attracted researcher's attention since

* استاذ/ كلية علوم الحاسبات والرياضيات/جامعة الموصل
** أ.م. / كلية علوم الحاسبات والرياضيات/جامعة الموصل
*** أ.م. / كلية علوم الحاسبات والرياضيات/جامعة الموصل

تاريخ التسلم : 8/ 4 /2006 ـــــــــــــــ تاريخ القبول : 26/ 9 /2006

about half century is order estimateion. Method of order estimation depends on the Artificial Intellegent techniques such as Neural Networks.
Perceptron network has been used for order discrimination and special Algorithim has been prepared for training the network. Special network has been proposed called (ONN) which has been trainied on many Markovian chains generated by simulation.

This study treated realistic data collected from this area, the order of this chain is estimated as the third.

المقدمة

تُعد عملية تقدير رتبة سلسلة ماركوف لتمثيل مشاهداتها من المسائل بالغة الأهمية في التطبيقات الواقعية، لما لها من علاقة بذاكرة السلسلة من خلال تحكمها ببعد النموذج، من ناحية أخرى فان أول شيء يتبادر إلى ذهن الباحث عند تحليله لسلسلة من المشاهدات هو أن كانت المشاهدات مستقلة (Independent) عن بعضها البعض، أو إن كانت هناك اعتمادية ما فيما بينها. فلو كانت مترابطة فيما بينها فيكون من المهم معرفة عدد الفترات التي تعتمد عليها القيمة الحالية من المشاهدة، وهذا بدوره يفيد كثيراً عند إجراء التكهنات المستقبلية للسلسلة.

يقترن مفهوم الرتبة (Order) للنموذج أو لسلسلة ماركوف رياضياً بمفهوم البعد المغمور (الضمني) (Embedding Dimention) ، وحاسوبيا بحجم الذاكرة (Memory Size) وتعرف الرتبة بانها اقل عدد صحيح موجب ممكن لعدد الحالات السابقة المباشرة التي يعتمد عليها احتمال الحالة القادمة ممثلة بحجم الذاكرة أو بالبعد المغمور (الضمني) أو بطول مدة التاريخ التي يعتمد عليها احتمال الحالة القادمة، فإذا ما اعتمد احتمال الحالة القادمة على m من الحالات السابقة مباشرةً، وكانت m اصغر عدد صحيح موجب ممكن، عندئذ فان m ستمثل رتبة سلسلة ماركوف، بحيث تحقق العلاقة الاحتمالية الاتية:

$$P = (X_{t+1} = j \mid X_t = i_o, X_{t-1} = i_1, \ldots, X_{t-m} = i_m) = P(X_{t+1} = j \mid X_t = i)$$

يتالف العضو السفلي لسلسة ماركوف لمنطقة بطمة من تعاقب ثلاثة انواع من الاحجار وهي حجر المارل (Marl) رمزه (A) والحجر الجيري المتحجري (Limestone) رمزه (B) والجبس (Gypsum) رمزه (C) ، تكونت نتيجة لعمليات الترسيب عبر فترات زمنية معينة مشكّلة طبقات عدة أو تتابعات صخرية على وفق ترتيب معين عرفت بسلسلة ماركوف غير المرحلية Non-Stationarity Markovian Chain، وعدد مشاهداتها (665) مشاهدة.

وتتطلب عملية استخدام الشبكات العصبية توفير او بناء قاعدة بيانات نوعية كي يتم تدريب الشبكة عليها، ولعدم توافر اعداد من سلاسل ماركوف الحقيقية المشابهة في ظروفها للسلسلة الاصلية موضوع البحث معلومة الرتبة، ولكون معظم السلاسل الحقيقية الطبيعية ليست ذوات رتب نقية (100%) عادة ما نلجأ الى اسلوب المحاكاة (Simulation) لتوليد سلاسل ماركوف من خلال نماذج الانحدار الذاتي (Autoregresive Models) الخطية وغير الخطية وبرتب قياسية معلومة مسبقا والتاكد من رتبتها القياسية عن طريق معيار معلومات اكاكي (Akaike's Information Criterion) (AIC)، واختير من بين تلك السلاسل المولدة عدد منتخب منها لتدريب الشبكة ومن خلالها تعرف وتحدد رتبة سلسلة ماركوف لمنطقة بطمة.

وقد صممت لهذا الغرض شبكة عصبية اصطناعية وهي شبكة المدرك لتمييز الرتب سميت (ONN) (Order Neural Network) نحصل بوساطتها على رتبة سلسلة ماركوف غير المرحلية لمنطقة بطمة، هذه الشبكة تعمل على وفق خوارزمية التدريب المعدة لهذا الغرض، اذ طبقت على حالات عدة من السلاسل المنتخبة للتعلم وبحسب قيمة مختارة لمعدل التعلم (نسبة التعلم) (Learning Rate) (η) وبعدد من الخطوات او مرات التدوير (Iteration Number) (In) للتوصل الى ادق النتائج وافضلها.

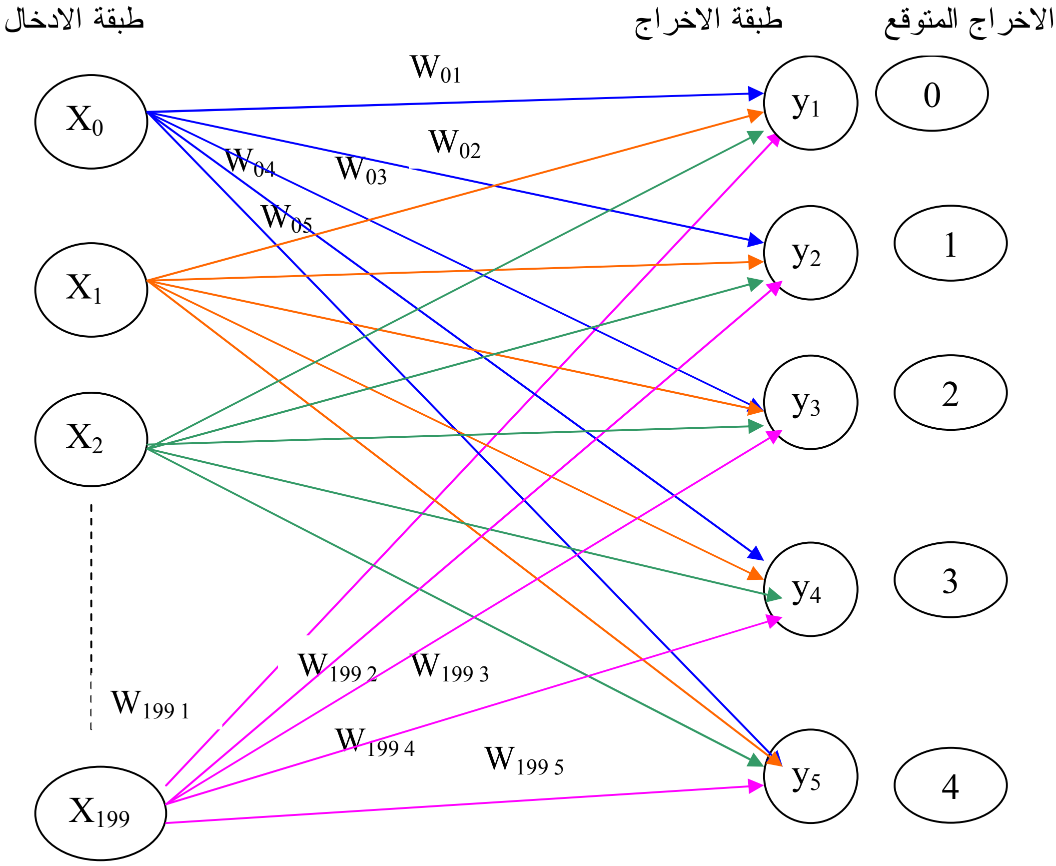
معمارية شبكة المدرك لتمييز الرتب

Perceptron Network Architecture of Order Discrimination

لتمييز الرتب في شبكة المدرك المكونة من طبقتـــين همـــا طبقتـــا الادخـــال والاخراج، فان طبقة الادخال تتكون من مجموعة خلايا، وحيث ان لكل رمز من رموز السلسلة المذكورة انفاً مـــدخلين (خليتـــين) فـــالرمز A مدخلاتـــه هـــي (1– 1–) و B (1 1–) و C (0 1) ، وان طول هذه السلسلة او عدد مشاهداتها هو (100) مشاهدة فلابد ان يكون عدد خلايا طبقة الادخال (200) خلية، في حين ان عدد خلايـــا طبقـــة الاخراج (5) خلايا الثانية والثالثة والرابعة والخامسة منها للرتب المعلومـــة الخاصـــة بنماذج الانحدار الذاتي يضاف اليها الخلية الاولى وهي الخلية التي لا تشبه أية رتبـــة من الرتب المعلومة مسبقاً لنماذج الانحدار الذاتي الخاصة بالمحاكاة.

ويحدد الاخراج المتوقع (Target Output) الخاص بالشبكة العصبية والسبب في ذلك يعود إلى ان شبكة المدرك تكون باشـــراف (Supervised)، وعـــدد خلايـــا الاخراج المتوقع هي خمس خلايا ايضا.

ويمكن توضيح معمارية شبكة المدرك الخاصة بتمييز الرتب (ONN) بالشكل (1).



الشكل (1): معمارية شبكة المدرك لتمييز رتبة سلسلة ماركوف لمنطقة بطمة.

فكرة عمل شبكة المدرك لتمييز الرتب

Processing of Perceptron Network of Order Discrimination

ان كل طبقة من طبقات الشبكة العصبية الاصطناعية ترتبط مع الطبقة التي تليها، فطبقة الادخال ترسل اخراجها إلى كل الخلايا في طبقة الاخراج، وان هذه الادخالات تضرب بالوزن المقابل لها، والناتج المتحقق يمثل نواتج الضرب والذي يسمى بمصطلح (NET_j)، ويحسب لكل خلية عصبية في الشبكة بالمعادلة الاتية:

$$NETj = \sum_{i=0}^{n} X_{ki} * W_{ij}$$

حيث ان:

NET_j تمثل اشارة NET للخلية j.

X_{ki} تمثل مصفوفة الادخال للسلسلة ذات التسلسل k و i هو تسلسل خلية الادخال في السلسلة.

W_{ij} يمثل الوزن في خلية ذات التسلسل i إلى خلية الاخراج ذات التسلسل j وان j يمثل الموقع j للخلية العصبية في الطبقة X_i الذي يمثل متجه الادخال.

n: يمثل طول متجه الادخال بعد حساب NET_j.

وان :

n=2 * No. of Observation

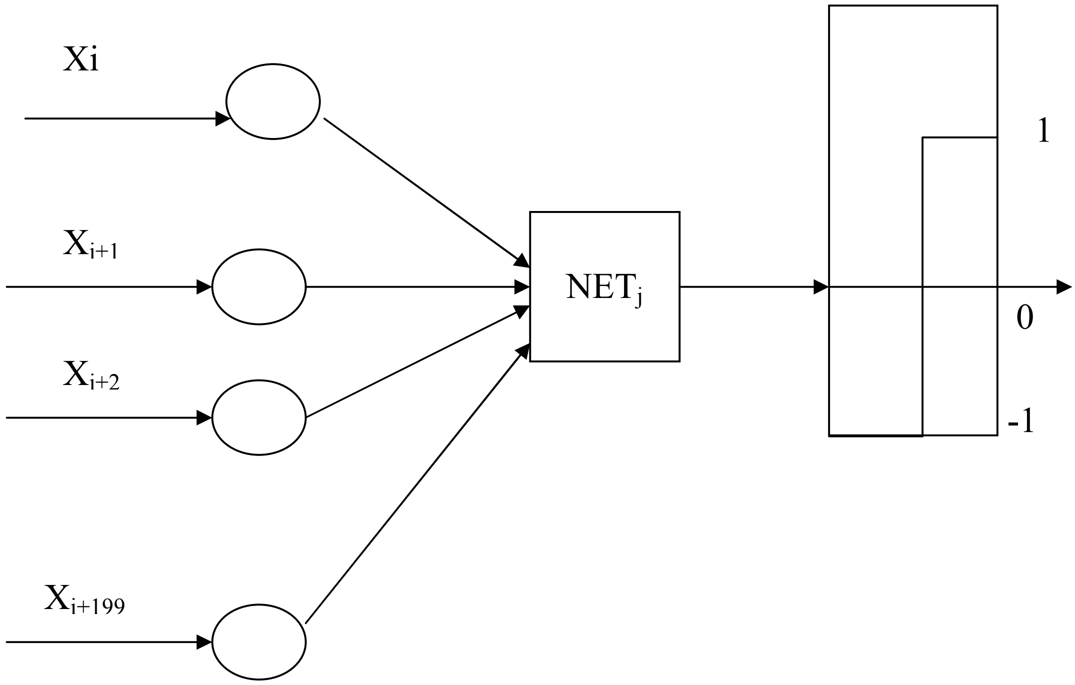
اما معادلة العتبة (Threshold) والتي كانت قيمتها ($\theta=1$) فهي كالاتي:

إذا كانت $\eta >$ Threshold فان output=1 تشبه الرتبة

إذا كانت $\eta <$ -Threshold فان output=-1 لاتشبه الرتبة نهائياً

إذا كانت -Threshold $< \eta <$ Threshold فان output=0 قريبة الشبه من الرتبة

والشكل (2) يوضح فكرة عمل شبكة المدرك لتمييز رتبة سلسلة ماركوف لمنطقة بطمة.



$$NETj = \sum_{i=0}^{199} X_{ki} * W_{ij}$$

الشكل (2) : فكرة عمل شبكة المدرك لتمييز رتبة سلسلة ماركوف لمنطقة بطمة.

خوارزمية التدريب لشبكة المدرك لتمييز الرتب (ONN)

Training Algorithm of Perceptron Network

ان الخوارزمية المقترحة لتدريب شبكة المدرك التي أُعد لها البرنامج الخاص بها ، يمكن تمثيلها بالخطوات الاتية:

1- الخطوة الاولى: اختيار قيمة اولية لمعدل التعلم (نسبة التعلم) (η) بحيث تكون ($0.1\leq \eta\leq 0.9$)

2- الخطوة الثانية: جعل عداد الخطأ E وعداد تسلسل السلسلةk مساويين للصفر

3- الخطوة الثالثة: يُحسب الاخراج وفق المعادلة الاتية:

O_j= limit (NET_j)

4- الخطوة الرابعة: يحسب الخطأ لكل اخراج وفق المعادلة الاتية:

$$E= E+(d_{kj}-O_j)^2$$

5- الخطوة الخامسة: تحديث الاوزان وفق الصيغة الاتية:

$$W_{ij} = W_{ij} +\eta(d_{kj}-O_j)$$

6- الخطوة السادسة: اضف للعداد k خطوة واحدة:

$$k=k+1$$

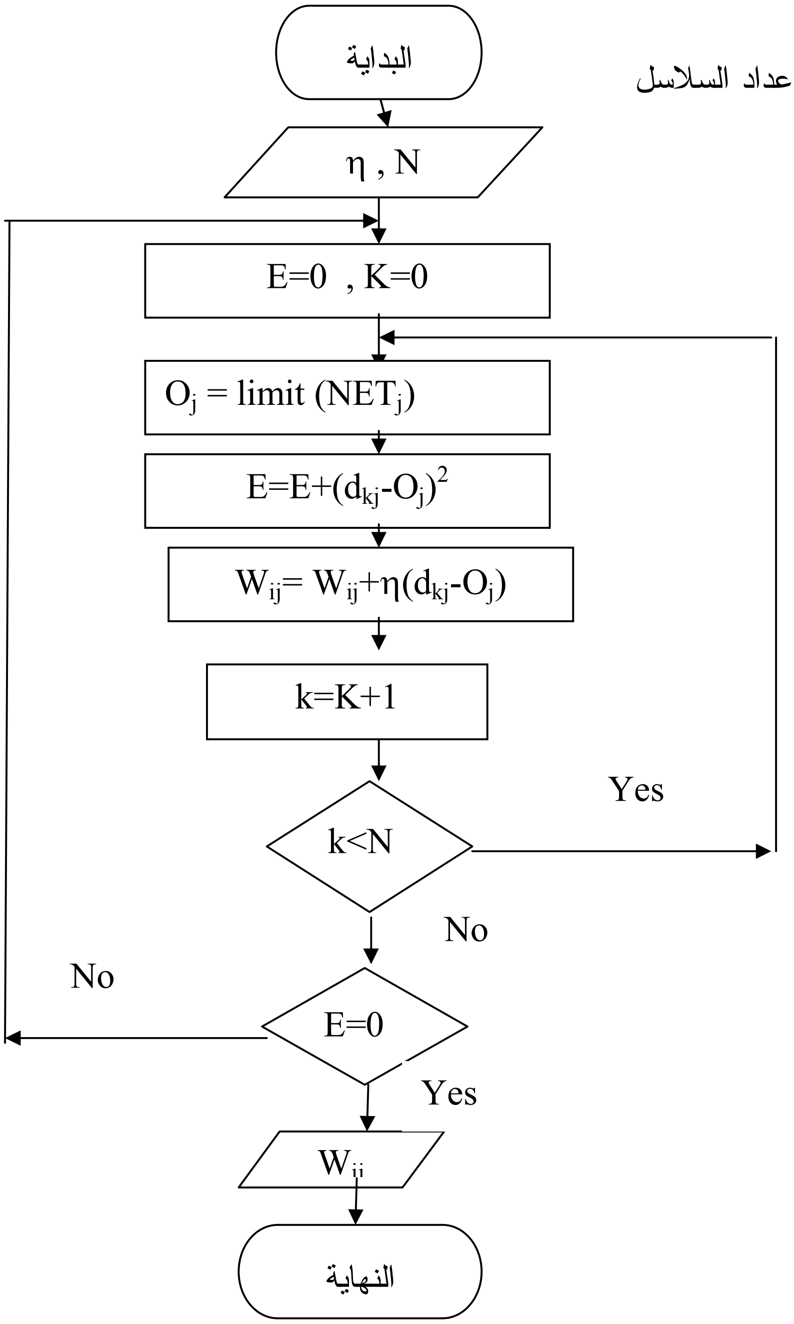
فاذا كانت k قد وصلت عدد حالات الادخال التي جرى اختبارها اقفز إلى الخطوة (7) والا الرجوع إلى الخطوة (3).

7- الخطوة السابعة: إذا كان عداد الخطأ E=0 نذهب إلى الخطوة (8) والا فالرجوع إلى الخطوة (2).

8- الخطوة الثامنة: اخزن قيمة الوزن النهائي المعلم (W).

ويمكن توضيح خطوات خوارزمية تدريب الشبكة بالمخطط الانسيابي المبين في الشكل (3)، وكالاتي:

N: عداد السلاسل



الشكل (3): المخطط الانسيابي لخوارزمية تدريب شبكة المدرك الخاصة بتمييز الرتب.

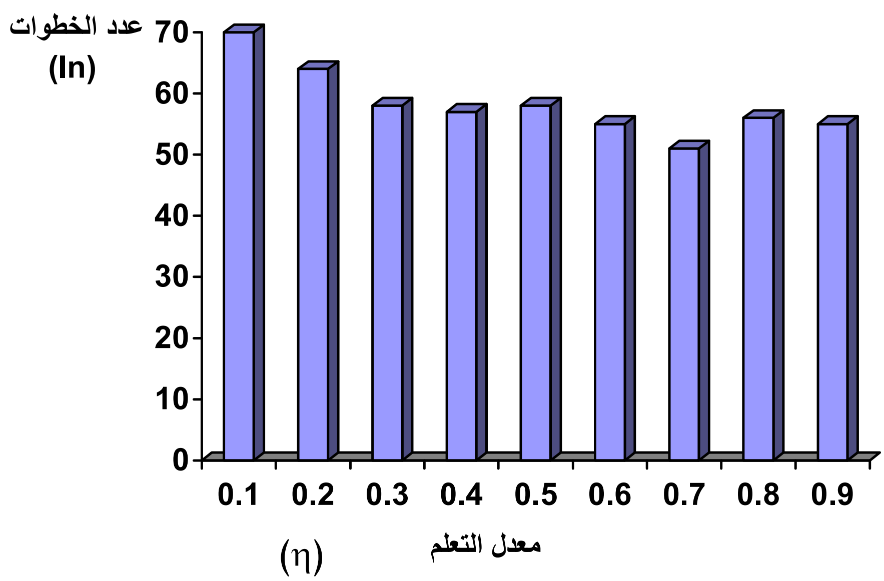
تاثير معامل معدل التعلم(نسبة التعلم) في عدد خطوات تدريب شبكة المـــدرك لتمييـــز الرتب (ONN)

لتمييز الرتبة في شبكة المدرك المتكونة من طبقتين، فان عدد خلايا الادخـــال (Input Units) والتي يرمز لها (Iu) سيكون (200) خلية في طبقة الادخال، في حين ان عدد خلايا الاخراج (Output Units) ورمزها (Ou) هو (5) خلايا فـــي طبقـــة الاخراج. ولمعرفة وبيان تاثير معدل التعلم (نسبة التعلم) (Learning Rate) (η) في عدد خطوات التدريب (.Iteration No) والذي يرمز له (In) في هذه الشـــبكة، فقـــد جربت جميع قيم (η) الواقعة ضمن المدى المسموح به ($0.1 \leq \eta \leq 0.9$) على فـــرض ان عدد سلاسل الادخال المنتخبة للتعلم ثابت وصغير وليكن (20) سلســـلة، ولُخصـــت النتائج في الجدول (1) بالاتي:

الجدول (1): تاثير معامل معدل التعلم في عدد خطوات التدريب وان عدد سلاسل الادخال N=20 سلسلة وعدد خلايا الادخال Iu=200 خلية وعدد خلايا الاخراج Ou=5 خلايا في شبكة المدرك لتمييز الرتب.

عدد سلاسل الادخال (N)	Iu	Ou	η	In	Time (Msec)
20	200	5	0.1	70	440
			0.2	64	385
			0.3	58	385
			0.4	57	330
			0.5	58	330
			0.6	55	330
			0.7	51	275
			0.8	56	330
			0.9	55	330

يتضح من الجدول (5–10) انه كلما زادت قيمة معدل التعلم (η) والتي تمثل قدرة الشبكة على الاستيعاب، قل عدد الخطوات ومن ثم قلّ الزمن المستغرق في انجاز هذه الخطوات، وان القيمة المثالية لمعدل التعلم (η=0.7) وهي التي تقابل اقل عدد ممكن من الخطوات واقل زمن، وعند زيادة قيمة معدل التعلم (η) عن القيمة المثالية نجد ازدياداً في عدد الخطوات والزمن ايضاً الا ان هذه الزيادة تبقى ثابتة. والشكل (4) يبين العلاقة بين معامل معدل التعلم وعدد الخطوات لشبكة المدرك لتمييز الرتب (ONN).



الشكل (4): العلاقة بين معامل معدل التعلم (η) وعدد خطوات التدريب (In) لشبكة المدرك لتمييز الرتب.

وبتثبيت قيمة معدل التعلم (η) عند القيمة المثالية التي حصلنا عليها (η=0.7) وبتغيير عدد سلاسل الادخـــال المنتخبـــة للـــتعلم (10، 15، 20، 25، 30،35، 40، 45،50، ...) تبين ان العدد المثالي للسلاسل المنتخبة التي سيتم تدريب الشبكة عليهـــا هو (45) سلسلة ادخال، فعند هذا العدد من السلاسل المنتخبة تكون الشبكة قد وصـــلت إلى الحد الاقصى للاستيعاب، ولو اردنا زيادة عدد سلاسل الادخال إلى اكثر من 45 سلسلة ادخال لكل رتبة توجب تغيير معمارية الشبكة (عدد خلايا الادخال والاخراج)، ولا داعي لمثل هذا التغيير في هذه الشبكة. وعند العدد (45) من سلاسل الادخال تكون الشبكة قد تعلمت ووصلت إلى مرحلة التعلم، وبزيادة عدد السلاسل المنتخبة عن (45) فان الشبكة تستغرق وقتا طويلاً جداً (ساعات عديدة)دون الحصول على نتيجة، ويعود سبب ذلك إلى ان الشبكة قد تعلمت بما فيه الكفاية وان اية زيادة في اعـــداد السلاســـل تؤدي إلى نسيان الشيء الذي تعلمته سابقاً (كأنما يحدث قطع في عملية التعلم) فتبقـــى تدور دون اية نتيجة، والجدول (2) يبين العلاقة بين قيمة معدل التعلم الثابتة المثاليـــة (η=0.7) والعدد الامثل لسلاسل الادخال المنتخبة.

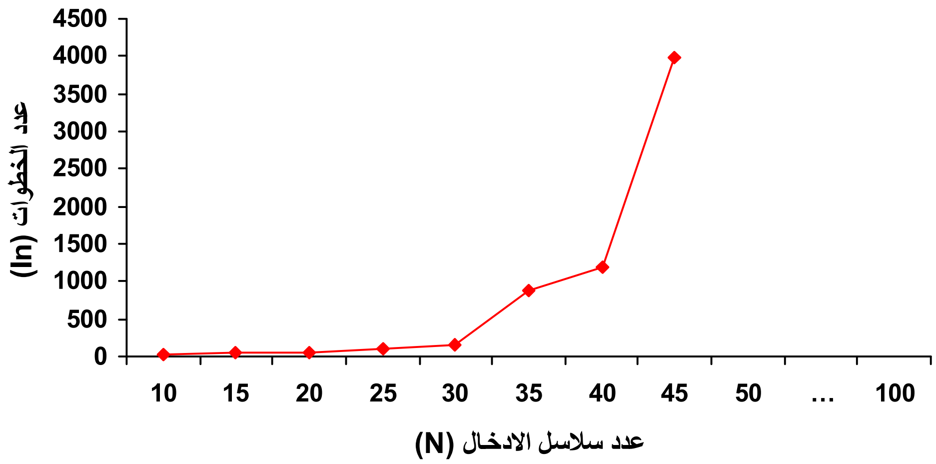
الجدول (2): العلاقة بين القيمة المثالية لمعدل التعلم (η=0.7) وان عدد خلايا الادخال Iu=200 خلية وعدد خلايا الاخراج Ou=5 خلايا لشبكة المدرك لتمييز الرتب.

عدد سلاسل الادخال (N)	Iu	Ou	η	In	Time (Msec)
10	200	5	0.7	23	55
15				47	220
20				64	385
25				110	770
30				150	1320
35				873	8635
40				1202	13695
45				3991	67540
50				-	-
55				-	-
-				-	-
65				-	-
70				-	-
75				-	-
80				-	-
85				-	-
90				-	-
95				-	-
100				-	-
-: عدم الحصول على اية نتيجة بعد مرور عدة ساعات.					

يتضح من الجدول (2) انه عند ثبات معدل التعلم عند القيمة المثالية فان العدد الامثل لسلاسل الادخال المنتخبة للتدريب هو (45) سلسلة لكل رتبة من الرتب المعلومة مسبقاٍ، وبزيادة عدد سلاسل الادخال عن (45) سلسلة فان الشبكة تتعلم ولكنها

لا تفهم ما تعلمته فتبقى تدور بعبارة اخرى فانها تعلمت ولكن قيمة الخطأ لم تصل إلى الصفر.

ان اية زيادة ولو كانت قليلة في عدد سلاسل الادخال المنتخبة تقابلها زيادة مضطردة وواضحة في عدد خطوات التدريب للشبكة، والشكل (5) يوضح العلاقة الطردية بين عدد سلاسل الادخال وعدد الخطوات بثبات قيمة معدل التعلم لشبكة المدرك لتمييز الرتب (ONN).



الشكل (5): العلاقة بين عدد سلاسل الادخال (N) وعدد الخطوات (In) لشبكة المدرك لتمييز الرتب (ONN).

تدريب شبكة المدرك لتمييز الرتب

Perceptron Network Training for Orders Discrimination

بعد الحصول على القيم المثالية لمعدل التعلم (η) ولعدد سلاسل الادخال القياسية (N) تدرب الشبكة على عدد من الامثلة ذوات النوعية الجيدة، والامثلة التي دربت عليها الشبكة هي اعداد هائلة من سلاسل ماركوف المولدة من نماذج الانحدار

الذاتي الخطية وغير الخطية معلومة الرتب، والتي تم اختبار رتبها باستخدام معيار معلومات اكاكي اذ اظهرت نتائجها تطابقا في هذه الرتب.

وقد تم اختيار (45) سلسلة ادخال موثوقاً بها لكل رتبة من الرتب المعتمدة، وبعد الحصول على نتائج الرتب الخاصة بجميع السلاسل غير المرحلية، نقوم بتوليد مجموعة بعدد قليل من السلاسل لتكن مثلا (10)، مهمتها اختبار صحة التدريب والتعلم، يطلق عليها اسم سلاسل اختبار التدريب. اما العدد الاكبر (المثالي) من السلاسل المنتخبة للتدريب وهو (45) سلسلة ادخال ولجميع الرتب فتسمى بسلاسل التدريب التي تستخدم في خوارزمية التدريب. وكما هو معلوم فان معالجة المعلومات داخل الشبكة تتم على مرحلتين اساسيتين هما مرحلة التعلم ومرحلة العمل او الاسترجاع، هنا تبدأ مرحلة التعلم على سلاسل الادخال بمعدل التعلم المثالي (η=0.7)، وبذلك تتدرب الشبكة ونحصل منها على اوزان التدريب المبينة في الملحق (D)، ثم تاتي مرحلة العمل او الاسترجاع لسلاسل التدريب للحصول على الرتب الخاصة بجميع سلاسل التدريب، ولاختبار مدى صحة التدريب من عدمه تجرى هذه المرحلة على سلاسل اختبار التدريب وبالاوزان التي حصلنا عليها من المرحلة الاولى، كي نتمكن من تحديد رتب هذه السلاسل.

ولتحديد رتبة سلسلة ماركوف غير المرحلية لمنطقة بطمة، وبعد اجراء التدريب المذكورة انفا يتم تقطيع هذه السلسلة الى عدد من سلاسل ماركوف بحيث يكون عدد مشاهدات كل سلسلة (100) مشاهدة، واختبار هذه السلسلة باستخدام الاوزان نفسها التي تم الحصول عليها من مرحلة التعلم لسلاسل التدريب وتجرى مرحلة العمل او الاسترجاع على تلك الاوزان للحصول على رتبة سلسلة ماركوف غير المرحلية لمنطقة بطمة، اذ تبين انها من الرتبة الثالثة والمبينة نتائجها في الشكل (6).

التسلسل	الرتب التي ميزتها الشبكة					اجزاء سلسلة ماركوف الواقعية لمنطقة بطمة
1				3.0		BBBBBBBBAAAAAAAAAAAAAAAACCCCBBBBCCCCCCAAAAAAABA BABBBBABABBBAAABCBBABBBABBBBBBBBBBABBAABBBBBAB BBCCCCCCC
1		1		3.0	4.5	BBBBBBBBBBBBBBBCCBBCCCCCCCCCCCCCC CCCCCCCCABAABBCCCCCCAAAACCABBBCCA AACCAABBAAAABAAAAAACCCAACCAAAAAA
1	0.0					AAAAAACCAABAAAAAABBCCCCCCCCCCCCC CCCCCCBACCCCAAABBCCCCCCCCCCCCCCCC AAAAAAAAABBBBCCCCCCCCCCCCCCCCCC
1	0.0		2.0	3.0	4.5	CCCCCCCCCCCCCCCCCCCCCCCCCCCCCCCC CCCCCCCCCCCCCCCCCCCCCCCCCCAAAAAAA AAAAAAAAAAAAAABBBBBBBBBBBBAAAAAA A
1	0.0					AAAAAABBBBBBBBBCCCCBAABBCCCCCCCCC CCCCCCCCCCAAAAAABBCCCCCCCCCCCCCCC CCCCCCCCABBACCCCCCCCCCCCCCCCCCB
1	0.0			3.0	4.5	CCCCCCCCCCCCCCBBBBBBCCCCCCCCCCCCCC CCCCCCCCCCCCCCBCCCCCCCCCCCCCCBBBBB BBBBBBBBBBBBBBBBBBBBBCCCCCBCCCCC
1			2.0	3.0		CCCBAAAAAAAABBCCCCCCCCAABBCCCCCCCC CCCCCCCCCCBBBBBBBCCACCCCACCCCCCCC CBAAAAAAAABBCCCCCCCCAABBCCCCCCCCCC

الشكل (6): نافذة الرتبة التي ميزتها شبكة المدرك (ONN) لسلسلة ماركوف الواقعية لمنطقة بطمة.

الاستنتاجات

في ضوء ماورد في البحث نعرض اهم الاستنتاجات النظرية والعملية بالاتي:

1- ان طبيعة المعالجة الاحصائية التي تقوم بها الشبكات العصبية التي تجمع بين العلاقات الخطية وغير الخطية، فضلا عن قدرتها العالية في التعامل مع اعداد هائلة من سلاسل ماركوف، جعلها الأوفر حظا في ان تكون الافضل من بين جميع الطرائق المستخدمة في هذه الدراسة.

2- الوقت والجهد المبذولان في عملية التحليل باستخدام الشبكات العصبية المتمثلة بتدريب الشبكة لمرات عديدة وتكرار ذلك لاكثر من مرة واحدة وباعداد مختلفة من سلاسل الادخال جعلها تعطي نتائج عالية الدقة، علما ان الطرائق والاساليب الاحصائية المستخدمة في تقدير الرتبة تحتاج الى وقت وجهد اكبر بكثير من الوقت والجهد المبذولين في تدريب الشبكات العصبية لغرض الحصول على الرتبة المناسبة.
3- قدرة الشبكات العصبية على توفير بدائل عديدة من السلاسل التي يتم محاكاتها لتمييز رتبة سلسلة ماركوف غير المرحلية (الواقعية) للتتابعات الصخرية لمنطقة بطمة.
4- يتلاشى قيد المرحلية عند استخدام اسلوب الشبكات العصبية لعدم قدرة الشبكة على تمييز الرتبة لسلاسل مختلفة الاطوال.

التوصيات

نستكمل ما انتهت اليه الاستنتاجات بالاتي:
1- في ضوء النتائج التي تم التوصل اليها من خلال معالجة سلاسل ماركوف باستخدام اسلوب الشبكات العصبية نوصي بضرورة استخدامها وبشكل متزامن مع قاعدة بيانات عريضة مكونة من العديد من سلاسل ماركوف الحقيقية، وعند تعذر الحصول عليها وعدم توافرها فمن الضروري جدا توليدها عن طريق المحاكاة.
2- في هذه الدراسة صممت شبكة عصبية مكونة من طبقتين وهي شبكة المدرك لتمييز الرتب والتي تتدرب عن طريق المشرف (Supervised) ، لذا نوصي بتصميم شبكة جديدة تتدرب بدون اشراف (Unsupervised) لتمييز الرتب كشبكة كوهين (Kohonen N. Network) مثلا.
3- نظرا لما تتمتع به الشبكات العصبية من مرونة عالية في عملها، فانه يجب توسيع استخدامها واقحامها في المواضيع والدراسات الاحصائية العديدة.

المصادر

1- الجراح، ريم علي. (2003): "**تحليل المكونات الاساسية باستخدام الشبكات العصبية الاصطناعية مع تطبيق**"، اطروحة دكتوراه، كلية علوم الحاسبات والرياضيات، جامعة الموصل، العراق.

2- الخياط، باسل يونس ذنون. (2002): "**تقدير رتب نماذج الانحدار الذاتي للسلاسل الزمنية**"، مجلة العلوم الاحصائية، وقائع المؤتمر العلمي الثالث عشر للجمعية العراقية للعلوم الاحصائية، تشرين الاول، بغداد، العراق.

3- العمري، ضحى عوني. (2004): "**استخدام شبكة التدرج المترافق في تشخيص التهاب المفصل العظمي**"، رسالة ماجستير، كلية علوم الحاسبات والرياضيات، جامعة الموصل، العراق.

4- Finesso, Lorenzo. ,(1991): **"Consistent Estimation of the Order for Markov and Hidden Markov Chains"**, Ph. D. , Dissertation.

5- Heyden, Marcel J. Vander. ,(1995): **"A note on the link between Neural Network and Statistics"**, heyden@rallf2.XS4 all.nl/node 1.thml.

6- Jian-Kang, Wu. ,(1997): **"Neural Networks and Simulation Methods",** Marcel Dekker, INC, New York.

7- Kanjilal, P.P. ,(1995): **"Adaptive Prediction and Predictive Control"**, Peter Peregrinus Ltd.

8- Priestley, M. B. ,(1981): **"Spectral Analysis and Time Series",** Academic Press, INC. ,(London) LTD.

9- Rao, Valluru. B., Rao, Hayagriva. V. ,(1993): **"C++ Neural Network and Fuzzy Logic"**, MIS: Press, New York.

10- Zurada, Jacek M. ,(1994): **"Introduction to Artificial Neural Systems"**, Jaico Publishing House, Mumbai.